

Power Quality Event Classification Using Least Square-Support Vector Machine

Ferhat Uçar

Fırat Üniversitesi, Elektrik Eğitimi, Elazığ

Ömer Faruk Alçın

Bingöl Üniversitesi, Elektrik Elektronik Mühendisliği, Bingöl

Beşir Dandıl

Fırat Üniversitesi, Mekatronik Mühendisliği, Elazığ

Fikret Ata

Fırat Üniversitesi, Elektrik Elektronik Mühendisliği, Elazığ

ABSTRACT

In this manuscript, a discrete wavelet transform and statistical feature extraction based intelligent pattern recognition system is presented which is efficacious to classify power quality disturbance events like voltage sags, swells and interruptions, harmonics and transients. One of main units in an intelligent system is classifier, here, Least Square-Support Vector Machine an improved version of support vector machine method is used as classifier unit. Power quality event data to be classify is derived via a simulation system based on detailed mathematical modelling which generates nearly real world signals. Given detailed results are obtained using conventional artificial neural networks and additionally extreme learning machine to evaluate performance more effectively.

Keywords: Power Quality, Pattern Recognition, Wavelet Transform, Support Vector Machine

Güç Kalitesi Olaylarının En Küçük Kareler-Destek Vektör Makinesi Kullanılarak Sınıflandırılması

ÖZET

Bu makalede, gerilim düşmesi, yükselmesi ve kesintisi, harmonikler ve geçici durumlar gibi güç kalitesi bozulma olaylarının sınıflandırılması amacıyla ayrık dalgacık dönüşümü ve istatistiksel verilere dayanan öznitelik çıkarımı tabanlı akıllı bir örüntü tanıma sistemi sunulmuştur. Akıllı sistemlerin temel bileşenlerinden olan sınıflandırıcı yapısında destek vektör makinesi yönteminin geliştirilmiş bir sürümü olan en küçük kareler-destek vektör makinesi kullanılmıştır. Sınıflandırılan güç kalitesi olay verileri detaylı olarak hazırlanan bir matematiksel model ile gerçek verilere en yakın şekilde oluşturulmuş benzetim sisteminden elde edilmiştir. Başarımın daha etkin değerlendirilmesi amacıyla geleneksel yapay sinir ağı yapısı ve ek olarak uç öğrenme makinesinden elde edilen detaylı sonuçlar da sunulmuştur.

Anahtar Kelimeler: Güç Kalitesi, Örüntü Tanıma, Dalgacık Dönüşümü, Destek Vektör Makinesi

1 GİRİŞ

Gelişen teknoloji ile birlikte elektrik şebeke yapısının geleneksel biçimden akıllı şebeke biçimine dönüştürülmesi günümüz elektrik sektörünün vazgeçilemez amacıdır. Üretim merkezlerinin yenilenebilir enerji kaynakları ile de çeşitlilik kazanmasıyla dağıtılmış üretim merkezleri ve ada tipi çalışma gibi şebekenin davranışını daha dinamik hale getiren yapılar da gün geçtikçe artmaktadır. Böylesi bir dinamik yapıda elektrik enerjisinin üretildiği yerden son kullanıcıya aktarılma sürecinde güç kalitesi kavramı büyük önem kazanmaktadır. Güç kalitesi sağlanarak aktarılan enerji, süreklilik ve güvenilirlik temelinde daha sürdürülebilir bir yapıya sahiptir. Şebekenin iletim ve dağıtım taraflarında oluşabilecek güç kalitesi problemleri iyi izlenmeli ve çözüm sürecinde hızlı, etkili adımlar atılmalıdır.

Akıllı şebeke sistemlerinde rol alan her bir eleman denetim merkezine bir takım veriler iletmektedir. Aynı şekilde denetim merkezinden de elemanlara doğru bir veri akışı söz konusudur. Bu çift yönlü iletişime sahip karmaşık yapıda anlık olarak kaydedilen verilerin ilgili kısmının anlamlandırılması ile güç kalitesi izleme sistemleri oluşturulmaktadır. Şebekenin akım-gerilim işaretlerinin takibine dayanan bu sistem, günümüzde artık büyük veri olarak tabir edilen geniş veri tabanlarını işleyerek operatöre anlamlı bilgi yumağını sunmaktadır. Büyük veri işleme sürecinde sistemin doğruluğu kadar işlem hızı da büyük önem kazanmıştır [1, 2].

Son birkaç on yılda, güç kalitesi olay verilerinin sınıflandırılmasına ilişkin literatüre kazandırılan birçok bilimsel çalışma mevcuttur [3]. Çalışmaların tümünde sunulan akıllı örüntü tanıma sistemlerinde temel olarak iki ana bileşen bulunmaktadır: Ayırt edici öznelikler çıkarım ve sınıflandırıcı bileşenleri. Günümüze kadar ortaya atılan çalışmalar güç kalitesi olay işaretine ait ayırt edici özelliklerin frekans ve zaman bölgelerindeki farklılıklardan belirlenebileceğini ortaya koymuştur. İlk kullanılan yöntemler arasında Fourier Dönüşümü (FD) gelmektedir [4]. FD frekans bölgesine taşıdığı işaret üzerindeki anomalileri zamandan bağımsız olarak göstermesiyle geride kalmaktadır. Geliştirilen Kısa Zamanlı FD(KZFD) yöntemi ile işaretlerdeki anomalilerin zaman bilgisine de ulaşılsa da işareti tararken kullanılan pencere genişliğinin sabit olması, meydana gelmiş bazı hızlı değişimlerin gözden kaçmasına neden olabilmektedir. Dalgacık Dönüşümü (DD), bir zaman/frekans dönüşüm yöntemi olarak ortaya atılmasından bu yana birçok uygulamada kullanım alanı oluşturmuştur [5]. KZFD yöntemine göre üstünlük olarak, incelenen işarete tarama gerçekleştiren pencere fonksiyonunun genişliğinin frekansa göre kendini uyarlaması söylenebilir böylece işaret boyunca gerçekleşecek tüm değişimler büyük oranda tespit edilmiş olur. Frekans ve zaman bilgilerini de belirlediği için DD yöntemi işaret işleme uygulamaları arasında öznelik çıkarımı kısmında önemli bir yere sahiptir. Literatürde Kalman Filtresi, Gabor dönüşümü, S dönüşümü, Hilbert-Huang dönüşümü gibi çeşitli dönüşüm tabanlı öznelik çıkarım yöntemi incelenmiştir [6, 7]

Akıllı sistemin karar mekanizmasını oluşturacak temel bileşen sınıflandırıcı yapısıdır. Hesapsal zeka yöntemlerinde meydana gelen çığır açıcı gelişmelerle birlikte son yıllarda çok çeşitli sınıflandırıcı yapıları ortaya konulmuştur [7]. Geleneksel Yapay Sinir Ağı (YSA) tabanlı sınıflandırıcılar hala geçerliliğini korumakla beraber eğitim süreci işlem hızlarının fazla olmasından dolayı büyük veri setlerini daha etkin şekilde işlemek için alternatif olarak birçok makine öğrenme yöntemi geliştirilmiştir [8]. İstatistiksel alt yapıya dayanan makine öğrenme yöntemleri başarımları ve hızları olarak iteratif yapıda ve geriye yayılım algoritması ile eğitim gerçekleştiren geleneksel yöntemlere göre daha çok tercih edilir hale gelmişlerdir. Güç kalitesi olaylarının sınıflandırılmasında YSA yapılarının yanı sıra uzman sistemler, istatistik tabanlı sınıflandırıcılar, bulanık mantık tabanlı sınıflandırıcılar, genetik algoritmaya dayanan sınıflandırıcılar, Destek Vektör Makinesi (DVM) yöntemi ile gerçekleştirilmiş sınıflandırıcılar olmak üzere çok farklı yöntemler kullanılmıştır [7]. Sahip olduğu yüksek işlem hızı ve genelleme yeteneği ile DVM yöntemi çeşitli alanlarda sınıflandırma ve regresyon işlemlerinde kullanılmaktadır [9]. DVM yönteminde genel olarak giriş işareti bir fonksiyon yardımı ile özellik uzayı olarak adlandırılan çok boyutlu düzleme aktarılmaktadır. Bu sayede sınıfları birbirinden ayırabilecek en uygun ortamı tespit etmede diskriminasyon işlemi sınıflandırıcının genelleme yeteneğini maksimize edecek şekilde tespit edilir. Sınıflandırmayı gerçekleştirecek en uygun yüzey ya da ortam optimizasyon teorisi ve İstatistiksel Öğrenme Teorisi yardımıyla belirlenir [9, 10]. DVM yöntemi, regresyon analizi yardımıyla çok sınıflı örüntü tanıma sistemlerinde de

başarılı sonuçlar ortaya koymaktadır. Bununla birlikte, En Küçük Kareler-DVM (EKK-DVM) yöntemi DVM'nin geliştirilmiş bir sürümüdür ki tüm üstün yönlerini barındırmakla beraber daha az hesap yükü ve optimizasyon yönteminin daha hızlı çözüm üretmesi özellikleri ile de var olan yöntemin önündedir. DVM'de kullanılan eşitsizlik kısıtlı optimizasyon yerine eşitlik kısıtlılığına dayanan yöntem odaklanması ile EKK-DVM işlem hızı ve genelleme başarımı olarak pozitif fark oluşturmaktadır [10].

Bu makalede, ayırt edici öznelikler DD dönüşümünün ayrıklaştırılmasına dayanan Ayırık Dalgacık Dönüşümü (ADD) yardımıyla çok çözünürlüklü ayrıştırma yönteminden ve ham verilere ait bazı istatistiksel verilere dayanarak elde edilmiştir. ADD detaylarına ait özneliklerin boyutunun azaltılması için detaylara Delta Standart Sapma (DSS) ve entropi ölçütü uygulanmıştır. Elde edilen tüm öznelik verileri EKK-DVM sınıflandırıcısı ile sınıflandırılıp karar uzayına taşınmıştır. Çalışmada ortaya konan akıllı örüntü tanıma sistemine ait blok diyagramı şekil.1'de gösterilmiştir. Ortaya konan sistem 3 ana kısımdan oluşmaktadır. Öncelikle yazılım ortamında gerçeğe çok yakın olarak elde edilen olay verileri ön işlem sürecinden geçirilerek normalize edilmiştir. Ön işlem sonrası ayırt edici özellikleri belirlemek için ADD dönüşümü çok çözünürlük analizi ve istatistiksel değerler hesaplanmıştır. Böylece özellik uzayına taşınan veriler tekrar normalize edilerek EKK-DVM sınıflandırıcısına giriş olarak sunulmuştur. Sınıflandırıcı çıkışında karar olarak güç kalitesi olay türü ortaya konmuştur. Sınıflandırıcı başarımını zor şartlarda test etmek adına 10-kat çapraz doğrulama yöntemi ile eğitim ve test süreçleri yinelenmiştir. Sonuçların değerlendirilme aşamasında geleneksel ileri beslemeli YSA (İB-YSA) ve uç öğrenme makinesi (UÖM) yöntemlerinden elde edilen sınıflandırma sonuçları da detaylı olarak sunulmuştur.

Bu çalışmanın devam eden bölümleri şu şekilde düzenlenmiştir: Bölüm 2'de güç kalitesi olay verilerinin elde edilmesine ait detaylar verilmiş ve benzetim sisteminin özelliklerine yer verilmiştir. Devamında sınıflandırılması yapılan güç kalitesi olaylarına ait grafiksel gösterimler sunulmuştur. Bölüm 3'te özneliklerin çıkarılmasında kullanılan ADD yöntemi ve istatistiksel veriler ile oluşturulan öznelikler detaylandırılmıştır. Bu bölümde ayrıca özneliklere ait bazı grafiksel detaylar da sunulmuştur. Bölüm 4'te sınıflandırma basamağında kullanılan EKK-DVM yöntemi özetlenmiştir. Bölüm 5'te elde edilen sonuçlar karşılaştırmalı olarak tablolar halinde sunulmuştur. Bölüm 6'da ise çalışmadan elde edilen sonuçlara ait tartışma ve değerlendirmeler sunulmuştur.



Şekil 1: Çalışmada sunulan akıllı örüntü tanıma sistemi blok yapısı

2 GÜÇ KALİTESİ OLAY VERİLERİNİN ELDE EDİLMESİ

Olay verilerinin elde edilmesi işlemini gerçekleştiren benzetim çalışması ile ilgili parametreler tablo 1'de sunulmuştur.

Tablo 1: Olay verilerinin elde edilmesi ile ilgili önemli benzetim parametreleri

Yöntem	Matematiksel Model
Yazılım Ortamı	Matlab R2014b Sürümü
Örnekleme ve Şebeke Frekansı	10 kHz – 50 Hz
Periyot Başına Örnek Sayısı	200
Benzetim Süresi	1 saniye
Toplam Örnek Sayısı	10.001
Olay Tür Sayısı	8 olay + 1 normal durum
Olay Verisi Sayısı	9x50 veri
Benzetim Boyunca Olay Periyot Sayısı	3-20 periyot arası
Pencere Tanımı	Olay Öncesi + Olay + Olay Sonrası
Eklenen Gürültü	20-50 dB

Tabloda belirlenen önemli parametreler, istenildiğinde kullanıcı tarafından değiştirilebilmektedir. Olay periyot sayısı, frekans değerleri, benzetim süresi, gürültü değeri ve veri sayısı değerleri esnek ve değiştirilebilir. Her bir olay örneği kendi içinde tamamen rastlantısal olarak ayarlanan başlangıç, bitiş ve olay türünün kendi özel değerleri ile bütünüyle eşsiz yapıdadır. Yani oluşturulan güç kalitesi bozulma üretici 9 farklı olay türünün her birinden 50 farklı örnek oluşturabilmektedir.

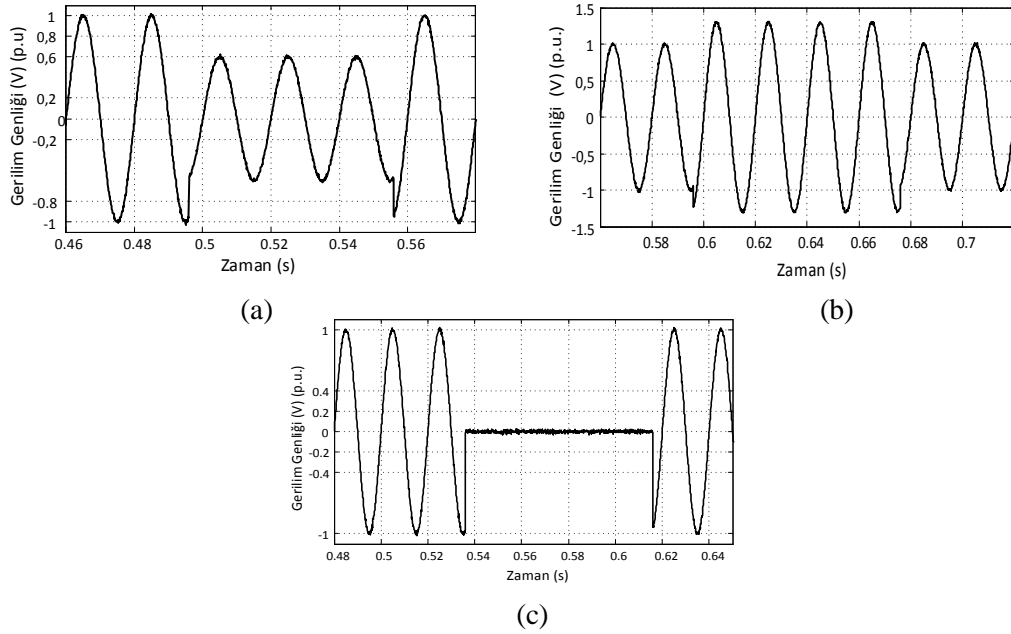
Tablo 2’de çalışmada sınıflandırması yapılan güç kalitesi bozulma olaylarına ait tür, etiket ve sayı bilgileri gösterilmiştir. Yapılan öncü deneyler neticesinde 50 adet örneğin öğrenme sürecini sağlıklı bir şekilde gerçekleştirdiği görülmüştür. Bu nedenle her bir olay türüne ait işaret sayısı 50 adet olarak belirlenmiştir.

Tablo 2: Matematiksel modelden elde edilen güç kalitesi olay türleri ve örnek sayıları

Güç Kalitesi Olay Türü	Sınıf etiketi	İşaret sayısı
Normal Sinüs	S1	50
Gerilim Çökmesi	S2	50
Gerilim Sıçraması	S3	50
Harmonik Bozulma	S4	50
Anlık Gerilim Kesintisi	S5	50
Gerilim Kırpışması	S6	50
Geçici Salınımlar	S7	50
Gerilim Çökmesi + Harmonik Bozulma	S8	50
Gerilim Sıçraması + Harmonik Bozulma	S9	50
Toplam		450

Çalışmada, sınıflandırıcı başarımını daha etkin değerlendirmek için sınıf sayısı artırılmıştır. Tek bir olay türünü içeren sınıfların yanı sıra birleşik olayları içeren iki sınıf tanımı daha yapılmıştır. Gerilim çökmesi ile harmonik bozulmanın ve gerilim sıçraması ile harmonik bozulmanın bir arada olduğu S8 ve S9 sınıfları, sınıflandırıcı yapısını zor şartlar altında sürmek amacıyla oluşturulmuştur.

Tablo 2’de listelenen ve benzetim modelinden elde edilmiş olan güç kalitesi olay işaretlerinden en önemlilerine ait dalga formları Şekil 2’de gösterilmiştir, burada sırasıyla gerilim çökmesi, yükselmesi ve anlık gerilim kesintisi işaretlerine ait örnek dalga formları verilmiştir.



Şekil 2: Güç kalitesi olaylarına ait örnek dalga formları a) Gerilim çökmesi, b) Gerilim Sıçraması, c) Anlık gerilim kesintisi

3 AYIRT EDİCİ ÖZNETELİKLERİN ELDE EDİLMESİ

Bu bölümde benzetim modeli yardımıyla elde edilmiş 450x10001 boyutundaki ham verinin her bir örneğine ait ayırt edici özneteliklerin elde edilmesinde kullanılan yöntemler sunulmuştur. İlk olarak ADD yöntemine ait detaylar verilmiş daha sonra da istatistiksel yollardan elde edilen özneteliklere değinilmiştir.

3.1 Ayrık Dalgacık Dönüşümü


DD yöntemi işaretlere bir zaman-frekans analizi ile bakmamızı sağlar. Bu nedenle işaret içerisinde gerçekleşmiş rutin dışı bir karakteristiklerin ortaya çıkmasına yardımcı olmaktadır. FD yöntemine ait en büyük dezavantaj olan zaman bölütleme kısıtlılığı kısa zamanlı FD yöntemi ile aşılabilmiş olsa da ortaya çıkan yeni dezavantaj kullanılan analiz penceresinin sabit olmasıdır. DD yöntemi ölçeklenebilir bir analiz penceresi kullanarak bu dezavantajı da ortadan kaldırmıştır. Yani işaretin seyri esnasında meydana gelen düşük frekanslı kısımlarla ilgili detayları ortaya koymak için geniş bir pencere, yüksek frekanslı kısımların detaylarını ortaya koymak için ise daha dar pencere kullanır. Bu özellik DD yönteminin ölçeklenebilir bir temel dalgacık fonksiyonu kullanmasıyla oluşmaktadır. Böylece işaret bir bütün olarak analiz edildiğinde daha esnek bir zaman-frekans analizi gerçekleştirilmiş olur [11]. Aşağıda (1) denkleminde sayısal hesaplamalara göre uyarlanmış ADD eşitliği verilmiştir:

$$ADD(m,n) = 2^{-m/2} \int y(t) \psi(2^{-m}t-n) dt \quad (1)$$

Denklem (1) ifadesinde m ile frekans ölçme parametresi, n ile de zamanda öteleme parametresi belirtilmiştir. İşlem gören işaret $y(t)$ ve temel dalgacık fonksiyonu ise $\Psi(t)$ ile gösterilmiştir.

İşlenecek olan işaretin örnekleme frekansının izin verdiği ölçüde ADD yöntemi çok çözünürlüklü analiz yapmamıza da olanak tanımaktadır. Bu işlem işareti filtrelerden geçirerek daha düşük frekanslardaki bileşenlerini ortaya çıkarmamızı sağlamaktadır [12]. İşaretlerin ayrıştırılacağı çok çözünürlük seviye sayısı teoride sınırsızdır ama uygulamalarda detaylar ancak son örnek sayısına inene dek ya da örnekleme frekansının yarılama sınırına dek devam ettirilebilir. Hangi frekans değerine dek inileceğine ait verilecek

karar detaylara ait entropi değerine bakılarak verilebilir [12]. Bu çalışmada güç kalitesi olay verilerinin detaylı analizi gerçekleştirilmiş ve ayırt edici özelliklerin daha belirgin vurgulanması için 8 seviye ayrıştırma yapılmıştır. Şekil.3'te gerilim çökmesi işaretine ait ADD analizi sonrası elde edilen çıktılar grafiksel olarak gösterilmiştir.



Şekil 3: Gerilim çökmesi işaretinin ADD ile çok-çözünürlük analizi

Şekil.3'te gösterilen ADD ayrıştırma sonuçlarından d1-d4 arası detaylarda bozulma olayının başlama ve bitiş anları sırasıyla 40 ve 120 ms olarak açık bir şekilde görülmektedir. Yani gerilim çökmesi için önemli bir bileşen olan olay süresi, bu analiz yardımıyla kolayca çıkarılabilir. Bununla birlikte olay sırasındaki gerilim azalma değeri bu analiz yardımıyla doğrudan elde edilemez.

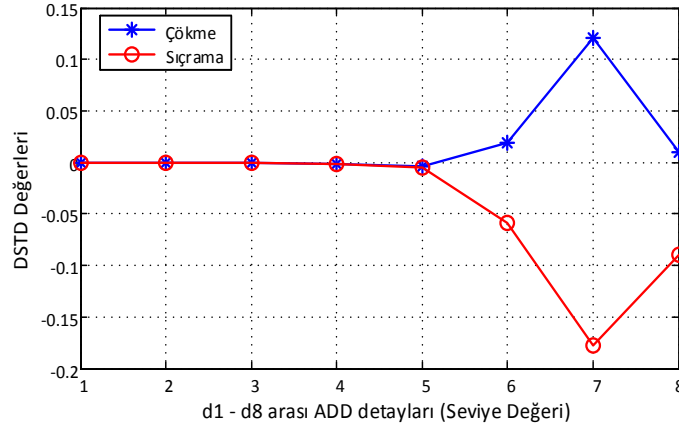
ADD yöntemi ile elde edilmiş olan detaylar, işaret ile aynı örnekleme değerine sahiptir. Herhangi bir işleme tabi tutulmadan sınıflandırıcıya aktarılamayacak yapıdadır. Bu nedenle d1 – d8 arası detaylara Delta Standart Sapma (DSTD) ve entropi ölçütü uygulanarak boyut indirgemesi yapılmıştır [13]. Böylece her olay verisini temsil eden 8 adet ayırt edici öznelik elde edilmiştir. Standart sapma (STD) hesabında (2) denkleminde gösterilen eşitlik kullanılmıştır. STD standart sapma değerini, d_j veri dağılımını, \bar{x} ortalama değeri ve N ise örnek sayısını ifade etmektedir.

$$STD = \sqrt{\frac{\sum_{j=1}^n (d_j - \bar{x})^2}{N}} \quad (2)$$

Olay işaretlerinin STD değeri alındığında birbirine yakın olaylar için öznelik yapılarının ayırt ediciliği tam olarak ortaya çıkmamaktadır. Bunu önleyip, sınıflandırıcı girişine daha kapsamlı özellikler göndermek amacıyla, delta standart sapma (DSTD) hesaplaması önerilmiştir [14]. DSTD hesaplaması; güç kalitesi olay verilerinin ADD detaylarından hesaplanan STD değerlerinin (STD_{Olay}), saf sinüs dalga şeklinin ADD detaylarından hesaplanan STD değerlerinden (STD_{Normal}) çıkarılmış halidir. Bu anlatım (3) denkleminde özetlenmiştir:

$$DSTD = STD_{Normal} - STD_{Olay} \quad (3)$$

Şekil.4'te gerilim çökmesi ve gerilim yükselmesi olaylarına ait DSTD değerleri grafik üzerinde gösterilmiştir.



Şekil 4: Gerilim çökmesi ve sıçraması olaylarına ait ADD detayları DSTD değerleri

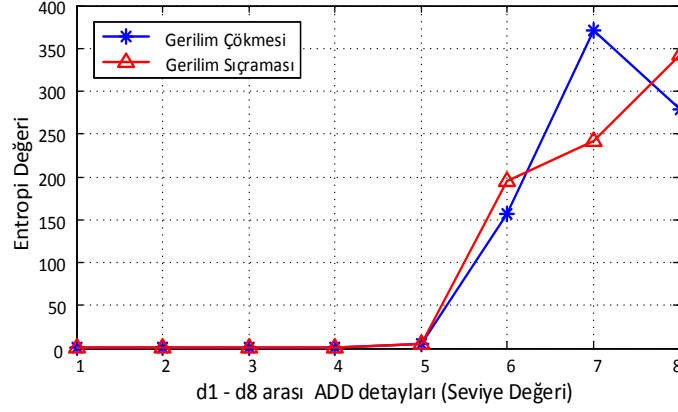
Şekil.4'ten açıkça görülebileceği gibi, DSTD işlemi sonucunda; yanlış sınıflandırılma olasılığı en yüksek olan çökme ve sıçrama olaylarına ilişkin, yüksek oranda ayırt ediciliğe sahip öznelikler elde edilmiştir.

Dalgacık detaylarından elde edilecek ayırt edici özneliklerin niteliklerini arttırmak amacı ile detay işaretlerine Entropi ölçütü de uygulanmıştır. Entropi genel olarak sisteme ait düzenlilik ya da düzensizlik kavramlarının ölçülmesi amacıyla termodinamik alanında yaygın kullanılan bir bilgidir [9]. İşaret işleme alanında kullanılan en önemli Entropi hesaplama yöntemleri; Shannon, Norm, Eşik, Logaritmik Enerji ve Sure yöntemleridir [15]. Bu çalışmada kullanılan Shannon entropi yöntemine ait matematiksel ifade denklem (4)'te gösterilmiştir. Burada s_i işareti; s_i ise işaretin i . katsayısını ifade etmektedir.

$$E(s) = - \sum_i s_i^2 \cdot \log_2(s_i^2) \quad (\log(0) = 0 \text{ kabulü yapılmıştır.}) \quad (4)$$

Bu çalışmada 8 seviye çok-çözünürlük ayrıştırma neticesinde elde edilen ADD detaylarına ait Entropi değerleri hesaplanarak her olay verisi için 8 adet öznelik elde edilmiştir.

Şekil.5'te gerilim çökmesi ve gerilim sıçraması olaylarına ait entropi değerleri birlikte gösterilmiştir. Ayırt edici özelliğin 5. seviyeden sonra ortaya çıktığı görülmektedir.



Şekil 5: Gerilim çökmesi ve sıçraması olaylarına ait ADD detayları DSTD değerleri

3.2 İstatiksel Değerlerden Elde Edilen Öznitelikler

ADD detaylarından elde edilen toplam 16 adet öznitelikğin yanı sıra her güç kalitesi olay işareti için ele alarak bir takım istatiksel veriler de edilmiş ve ayırt edici öznitelik olarak kullanılmıştır. Tablo 3'te çalışmada kullanılan istatiksel ifadeler listelenmiştir. Böylece özellik uzayına taşınan veri sayısı 24'e indirgenmiştir. Yani 10kHz örnekleme frekansında 1s için üretilen 1x10001 boyutundaki bir olay işareti 1/416 oranında azaltılarak 1x24 değerine düşürülmüştür.

Tablo 3: Öznitelik Çıkarmada kullanılan bazı istatiksel veriler ve açıklamaları

İstatiksel Veriler	Açıklama
min	Minimum değer
max	Maksimum değer
median	Dağılımın ortanca değeri
std	Standart sapma
mean	Ortalama değer
mode	Dağılımın tepe değeri
skewness	Çarpıklık
kurtosis	Basıklık

4 EN KÜÇÜK KARELER – DESTEK VEKTÖR MAKİNELERİ

DVM yöntemi dış bükey optimizasyonu tabanlı yapısal riski minimize etme ilkesine göre çözüm üreten makine öğrenme algoritmasıdır [16]. Diğer bellek tabanlı algoritmalarından aykırı olarak işleyeceği veri setine ait herhangi bir dağılım fonksiyonu bilgisine ihtiyaç duymamaktadır. Bu nedenle DVM veri dağılımından bağımsız bir öğrenme algoritması çalıştırmaktadır [10]. Örüntü tanıma ve regresyon süreçlerinde görüntü işleme, hastalık teşhisleri ortaya koyan tıbbi işaret işleme uygulamaları gibi birçok alanda etkin olarak kullanılmaktadır [17]. Temel olarak istatistiksel öğrenme teorisine dayanır ki bu teori Vapnik-Chervonenkis (VC) teorisi olarak da bilinmektedir [17].

DVM temel olarak iki sınıfı birbirinden ayırmak için çalışan bir öğrenme algoritmasıdır. Çok sınıflı uygulamalarda her biri yine iki sınıf için karar veren DVM yapıları belli karar mekanizmaları ile eğitilerek çalıştırılmaktadır [18]. DVM yönteminin amacı sınıfları birbirinden ayıracak en uygun hiper düzlemi belirlemektir. Sınıfların bir birine en yakın olan elemanları üzerinden geçen vektörlere destek vektörler denir ki nihai amaç bu iki sınıf sınırında bulunan destek vektörler arası uzaklığın maksimize edilmesi anlayışına dayanmaktadır. Doğrusal olarak ayrılabilen ve doğrusal olarak ayrılamayan sınıf yapılarının her

ikisi için de DVM tasarlanabilmektedir. Doğrusal olarak ayrılamayan sınıflar için DVM verileri bir çekirdek (Kernel) fonksiyonundan geçirerek çok boyutlu uzaya taşır ve bu yeni ortamda belirlenecek bir yüzey ile veriler doğrusal olarak ayrılabilir [17].

DVM yönteminde yukarıda özetlenen optimizasyon işlemi kuadratik programlama probleminin çözümünü işaret eder ki matematiksel olarak lineer denklem takımlarının olduğu bir uygulamaya göre karmaşık çözümler içerir [17]. Bu nedenle DVM yöntemine alternatif olarak yine çekirdek (kernel) tabanlı öğrenme algoritması sınıfına giren EKK-DVM yöntemi Suykens ve Vandewalle tarafından önerilmiştir [18]. DVM yönteminde olduğu gibi dış bükey kuadratik optimizasyon yöntemi yerine EKK-DVM'de doğrusal denklem takımlarının çözülmesi ile sonuca ulaşılmaktadır. Bu özelliği ile öğrenme sürecine hız katan EKK-DVM yöntemi de geleneksel yapıya göre birçok uygulamada tercih edilir hale gelmiştir. EKK-DVM ve DVM yapısına ait detaylı alt yapı bilgisine [19, 20] çalışmalarından ulaşılabilir.

5 SONUÇLAR

Bölüm 2'de detayları verilen matematiksel model tabanlı benzetim sisteminden elde edilen güç kalitesi olay verilerine ait detaylar Tablo 2'de detaylı olarak gösterilmiştir. Bu bölümde, tasarlanan örüntü tanıma sistemine ait sınıflandırma başarımları detaylandırılmıştır. Başarım değerleri EKK-DVM sınıflandırıcısının yanı sıra UÖM sınıflandırıcı, İB-YSA sınıflandırıcı yapıları kullanılarak elde edilmiştir. 10-kat çapraz doğrulama yöntemi kullanıldığı için başarım değerleri ortalama değerler ve 10'luk dizinin en küçük ve en büyük değerleri ile gösterilmiştir. Ayrıca eğitim ve test süreleri de dikkate alınmıştır. Benzetim sonuçları 2.6 GHz çift çekirdekli ile 6 GB belleğe sahip bir bilgisayar kullanılarak elde edilmiştir.

Tablo 4'te EKK-DVM, İB-YSA ve UÖM sınıflandırıcıya ait ortalama başarım değerlerini ve dikkate alınan ortalama ve test sürelerini göstermektedir.

Tablo 4: Örüntü tanıma sistemine ait benzetim sonuçları: 50 dB gürültü şartında

Sınıflandırıcı	Doğruluk (%)			Zaman (s)	
	Ortalama	En yüksek	En düşük	Eğitim	Test
EKK-DVM	97	98,5	95,4	0,2309	0,1888
İB-YSA	65	74,5	57,3	1,5350	0,9112
UÖM	96	97,8	94,1	0,1563	0,0047

Sınıflandırıcı başarımlarını etkin bir şekilde değerlendirilmek üzere gerçek verilere en yakın şekilde elde edilmiş ve 50 dB sinyal gürültü oranına sahip Gaussian gürültü eklenerek oluşturulmuş güç kalitesi verilerinin sınıflandırılması ile elde edilen benzetim sonuçları incelendiğinde başarım olarak öne geçen sınıflandırıcı EKK-DVM tabanlı yapıdır. Geleneksel YSA yapısının bu işlem için uygun sonuç vermediği görülmektedir. Ayrıca eğitim ve test süreleri incelendiğinde yine İB-YSA sınıflandırıcısının diğer yapılara göre geride kaldığı görülmektedir. Süreler açısından yapılan değerlendirmede UÖM yapısı diğer sınıflandırıcıların önüne geçmiştir. Eğitim ve test sürelerinde EKK-DVM yöntemi başarım olarak önüne geçtiği UÖM yapısının gerisinde kalmıştır.

Tablo 5'te aynı verilere ait 20 dB şartındaki benzetim sonuçları gösterilmiştir. Gürültü değerinin gerçek değerlerin üzerine çıkarılarak sistemin daha da zorlandığı bu çalışma şartında sınıflandırıcı başarımlarında genel olarak bir düşüş gözlenmiştir. Bütüncül olarak ele alındığında bu değişimin kabul edilebilir sınırlar içinde olduğu görülmektedir.

Tablo 5: Örüntü tanıma sistemine ait benzetim sonuçları: 20 dB gürültü şartında

Sınıflandırıcı	Doğruluk (%)			Zaman (s)	
	Ortalama	En yüksek	En düşük	Eğitim	Test
EKK-DVM	94	0,986	0,911	0,2120	0,1766
İB-YSA	0,61	0,6325	0,551	3,0578	0,9010
UÖM	0,95	0,980	0,921	0,0375	0,0027

Tablo 6’da EKK-DVM sınıflandırıcısı kullanıldığında 10 kat çapraz doğrulama uygulanan veri paketlerinden birisine ait bir doğruluk tablosu gösterilmiştir. Bu tabloda sınıflandırıcı kararı ve gerçek verinin sınıflar arası yorum yaparak ne kadar uyduğunu belirleyebiliriz. Tablodan görülebileceği üzere bu veri paketinin doğruluğu son derece yüksektir. Genel durumda sadece S3 sınıfı olarak verilen gerilim sıçraması olayı ile S7 sınıfı olarak verilen geçici salınımlar olayının bir örnekte yanlış çıkış olarak üretildiği görülmektedir. Diğer tüm sınıflar tümüyle doğru karar olarak üretilmiştir.

Tablo 6: Bir veri paketine ait sınıf doğruluk tablosu

SINIFLANDIRICI KARARI										
GERÇEK VERİ	SINIFLAR	S1	S2	S3	S4	S5	S6	S7	S8	S9
	S1	6	0	0	0	0	0	0	0	0
	S2	0	8	0	0	0	0	0	0	0
	S3	0	0	3	0	0	0	1	0	0
	S4	0	0	0	3	0	0	0	0	0
	S5	0	0	0	0	4	0	0	0	0
	S6	0	0	0	0	0	6	0	0	0
	S7	0	0	0	0	0	0	2	0	0
	S8	0	0	0	0	0	0	0	6	0
	S9	0	0	0	0	0	0	0	0	6

6 TARTIŞMA VE DEĞERLENDİRME

Bu çalışmada, matematiksel modele dayalı benzetim sistemi kullanılarak oluşturulan güç kalitesi olaylarının akıllı sınıflandırmasını gerçekleştiren bir örüntü tanıma sistemi gösterilmiştir. Veri setindeki ayırt edici özellikleri ortaya çıkarmak üzere ADD tabanlı çok çözünürlüklü analiz gerçekleştirilmiştir. Buna ek olarak verilerin bazı istatistiksel özellikleri de hesap edilmiş ve ayırt edici özellik olarak kullanılmıştır. Elde edilen bu özellikler EKK-DVM ile sınıflandırılmış ve başarımlar değerlendirilmiştir. İB-YSA ve UÖM yöntemleri ile yapılmıştır. Makalede kullanılan EKK-DVM yapısına ait sonuçların diğer yöntemleri başarımlar olarak geride bıraktığı görülmektedir. Süre olarak ise UÖM yöntemi ön geçmiştir.

KAYNAKLAR

- [1] Colak, I., Bayindir, R., Fulli, G., Tekin, I., Demirtas, K. and Covrig, C. F. (2014). Smart grid opportunities and applications in Turkey. Renewable and Sustainable Energy Reviews, 33, 344-352.

- [2] Ribeiro, P. F., Duque, C. A., Ribeiro, P. M. and Cerqueira, A. S. (2013). Power systems signal processing for smart grids. John Wiley & Sons.
- [3] Khokhar, S., Zin, A. A. B. M., Mokhtar, A. S. B. and Pesaran, M. (2015). A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renewable and Sustainable Energy Reviews*, 51, 1650-1663.
- [4] Styvaktakis, E., Bollen, M. H. and Gu, I. Y. (2002). Expert system for classification and analysis of power system events. *Power Delivery, IEEE Transactions on*, 17(2), 423-428.
- [5] Styvaktakis, E., Bollen, M. H. and Gu, I. Y. (2002, July). Automatic classification of power system events using RMS voltage measurements. In *Power Engineering Society Summer Meeting, 2002 IEEE (Vol. 2, pp. 824-829)*. IEEE.
- [6] Manjula, M. and Sarma, A. V. R. S. (2012). Comparison of empirical mode decomposition and wavelet based classification of power quality events. *Energy Procedia*, 14, 1156-1162.
- [7] Mahela, O. P., Shaik, A. G. and Gupta, N. (2015). A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*, 41, 495-505.
- [8] Bollen, M. H. and Gu, I. (2006). *Signal processing of power quality disturbances (Vol. 30)*. John Wiley & Sons.
- [9] Ekici, S. (2009). Classification of power system disturbances using support vector machines. *Expert Systems with Applications*, 36(6), 9859-9868.
- [10] Ekici, B. B. (2014). A least squares support vector machine model for prediction of the next day solar insolation for effective use of PV systems. *Measurement*, 50, 255-262.
- [11] Barros, J., Diego, R. I. and De Apraiz, M. (2012). Applications of wavelets in electric power quality: Voltage events. *Electric Power Systems Research*, 88, 130-136.
- [12] Uyar, M., Yildirim, S. and Gencoglu, M. T. (2008). An effective wavelet-based feature extraction method for classification of power quality disturbance signals. *Electric Power Systems Research*, 78(10), 1747-1755.
- [13] Bollen, M. H., Gu, I. Y., Axelberg, P. G. and Styvaktakis, E. (2007). Classification of underlying causes of power quality disturbances: deterministic versus statistical methods. *EURASIP Journal on Applied Signal Processing*, 2007(1), 172-172.
- [14] M. A. Dandwate and P. K. B. Khanchandani, (2014). Generation of Mathematical Models for various PQ Signals using MATLAB. "International Conference On Industrial Automation And Computing," Lonara, Nagpur, April 12-13, 2014, 47-51.
- [15] Vapnik, V. N.. and Vapnik, V. *Statistical learning theory (Vol. 1)*. New York, Wiley. 1998
- [16] Gencoglu, M. T.. and Uyar, M. (2009). Prediction of flashover voltage of insulators using least squares support vector machines. *Expert Systems with Applications*, 36(7), 10789-10798.

- [17] Ayhan, S.. and Erdođmuş, Ő. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 9(1). 175-201.
- [18] Yakut, E., Elmas, B.. and Yavuz, S. (2014). Yapay sinir ađları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini. Suleyman Demirel University Journal Of Faculty Of Economics & Administrative Sciences, 19(1). 139-157.
- [19] Van Gestel, T., De Brabanter, J., De Moor, B., Vandewalle, J., Suykens, J. A. K.. and Van Gestel, T. (2002). Least squares support vector machines (Vol. 4). Singapore: World Scientific.
- [20] Dalei, J.. and Mohanty, K. B. (2016). Fault classification in SEIG system using Hilbert-Huang transform and least square support vector machine. International Journal of Electrical Power & Energy Systems. 76, 11-22.